

Utilização de algoritmos genéticos para seleção de áreas corticais ótimas em ICMs auditivas

Júlia Nepomuceno Mello
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brazil
ORCID: 0000-0002-5952-0583

Ana Clara Pereira Resende da Costa
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brazil
ORCID: 0000-0002-5533-8880

Ailton Luiz Dias Siqueira Júnior
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brazil
ORCID: 0000-0002-8944-5625

Alcimar Barbosa Soares
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brazil
ORCID: 0000-0003-1100-3533

Resumo — Interfaces Cérebro-Máquina (ICM) são importantes sistemas de comunicação alternativa para pacientes com paralisias motoras graves. Dentre os desafios para elaboração desses sistemas encontra-se a relação entre o número de eletrodos e a performance do sistema que esteja associado a um maior conforto para o usuário, menor tempo de processamento e performance elevada do sistema. O presente trabalho buscou otimizar um subconjunto de eletrodos em um escopo de eletrodos já previamente estabelecido como relevante para análise do potencial P300 em paradigma oddball visando aplicações em ICM. O protocolo experimental consistiu na apresentação de cinco tons alvos intercalados em um padrão de estímulos frequentes. A partir dos dados coletados, um algoritmo genético buscou otimizar a seleção de canais de eletrodos baseado na maximização da acurácia de classificação. A amplitude e latência do potencial P300 foi utilizada para a classificação das respostas. Foi possível encontrar subconjuntos de eletrodos diferentes para cada voluntário e frequência de análise, destacando assim a importância de análises individuais e anteriores a elaboração do sistema final para o usuário. Percebeu-se ainda um aumento da acurácia do sistema quando submetido aos dados provenientes dos eletrodos otimizados, corroborando para a necessidade de avaliação prévia. Conclui-se o algoritmo proposto é eficaz para a seleção das áreas corticais mais relevantes, sendo assim uma importante ferramenta para ICM mais adaptáveis e eficazes para cada usuário final.

Palavras-chaves — otimização, ICM, áreas corticais, AG

I. INTRODUÇÃO

As Interfaces Cérebro-Máquina (ICM) consistem em sistemas que permitem a comunicação e controle sem utilizar os canais de saída naturais do cérebro, ou seja, nervos periféricos e músculos [1], [2]. Assim, tais sistemas são um conjunto de *software* e *hardware*, que traduz os padrões de atividade cerebral de um usuário em mensagens ou comandos para um dispositivo, sendo essa atividade mediada e processada pelo sistema [2]. Por se basearem em sinais oriundos diretamente da atividade cortical, essas apresentam-se como os melhores candidatos de comunicação alternativa para pessoas com paralisias motoras graves, tais como indivíduos com Esclerose Lateral Amiotrófica (ELA) [1], [2].

Indivíduos com Esclerose Lateral Amiotrófica enfrentam uma perda contínua de funções, autonomia e habilidades de comunicação, sendo que os casos mais graves evoluem para síndrome do encarceramento [3]. Caracterizada por uma paralisia completa, os indivíduos que apresentam essa

síndrome estão presos dentro de seus próprios corpos, incapazes de interagir com o mundo externo [4]. Dessa forma, apesar de sua rara incidência, essa doença possui um grande impacto pessoal e socioeconômico para o paciente, sua família e a sociedade [5]. Dessa forma, as ICMs são uma importante tecnologia para reinserção social dos indivíduos no mundo, contribuindo assim para a melhora de sua qualidade de vida [4].

Nesse contexto, apesar dos grandes avanços nos diversos aspectos relacionados a ICMs, essas ainda possuem desafios que permeiam sua eficácia e funcionalidade como ferramenta de comunicação e controle de dispositivos. Dentre esses desafios, destacam-se dificuldades intrínsecas aos dados eletroencefalográficos (EEG) utilizados para o controle desses sistemas, tal como a baixa relação sinal-ruído [2], [6], [7], a dificuldade de posicionamento de eletrodos somente em locais de interesse para observação de determinados eventos neurais [8], [9] e o desconforto que pode ocorrer no usuário devido ao grande número de eletrodos posicionados no escalpo [10]. Assim, apesar do grande número de eletrodos de EEG estar diretamente relacionado a um maior acesso a regiões mais específicas do cérebro e uma maior resolução espacial [11], esse pode levar também ao aumento de artefatos presentes em alguns canais e que podem contribuir para degradar o desempenho dos sistemas de análise [9]. Além disso, eletrodos vizinhos podem gravar sinais elétricos semelhantes, contribuindo para um aumento de informações redundantes que não apresentam informações adicionais relevantes para a distinção entre respostas corticais [11].

Dessa maneira, uma redução do número de canais pode assim reduzir tempo de processamento, remover fontes de artefatos e diminuir tempo de operação de equipamentos a eles associados [12], tal como Interfaces Cérebro-Máquina (ICM). Além disso, um menor número de eletrodos é mais confortável para o usuário [11], [12], reduz o tempo de preparação e posicionamento desses e diminui o consumo de energia do equipamento de EEG [11]. Por fim, a redução de dimensionalidade consequente da redução do número de eletrodos de EEG contribui para a redução da complexidade computacional durante a análise dos sinais, melhorando a classificação desses e reduzindo o tempo de processamento [9], [13]. Essas características são fundamentais para a construção de equipamentos portáteis [8].

Dessa forma, métodos de seleção de canais automatizados são fundamentais, principalmente considerando que os canais

ideais de EEG são dependentes da aplicação desejada, tal como o estudo dos denominados Potenciais Relacionados a Eventos, comumente utilizado em ICMs [11]. Assim, dentre as técnicas de seleção de canais propostas na literatura tem-se métodos baseados em medidas estatísticas dos sinais [13], eliminação reversa [11], informação mútua [11], [13] e padrão espacial comum [9], [11], [13]. Recentemente, outra técnica que vem sendo investigada e apresenta resultados promissores consiste na aplicação de algoritmos genéticos (GA) [10]–[12], [14], [15], e outras técnicas de algoritmos evolutivos, tal como otimização de enxame de partículas modificadas [9]. Destacando-se os algoritmos genéticos, esses visam imitar a evolução darwiniana e utilizar operadores inspirados biologicamente para resolver problemas complexos [14], tal como a seleção de canais de EEG.

Portanto, sabe-se que a utilização de algoritmos genéticos para redução de uma grande quantidade de eletrodos, tal como 64 ou 32 eletrodos, já foi demonstrada para diversas aplicações, tal como em ICMs [10], [11], [15], sistemas de identificação de pessoas [12], [14] e classificação de tarefas mentais [13]. Tal redução representa, conseqüentemente, a seleção das áreas corticais que são mais relevantes para as análises realizadas considerando determinada tarefa. Em ICMs baseadas no potencial P300, consta na literatura a prevalência desse potencial em regiões centrais e parietais [16], contudo estudos demonstram que os canais otimizados nem sempre estão associados somente a essas regiões [15]. Sendo assim, este estudo busca avaliar se mesmo dentro de um escopo e eletrodos já diretamente relacionados a tarefa, é possível otimizar a seleção das áreas corticais analisadas, visando assim um aumento da performance da ICM, uma melhor portabilidade dos dispositivos e maior conforto para o usuário.

Para isso, o presente trabalho busca otimizar as áreas analisadas durante uma tarefa de paradigma *oddball* auditivo, buscando-se aprimorar a acurácia de classificação de uma Máquina de Vetores de Suporte. Deste modo, realizou-se um procedimento experimental envolvendo um conjunto de tarefas baseadas em diferentes frequências sonoras representando o estímulo alvo, em um contexto de estímulos padrão frequentes. O algoritmo genético projetado visa assim aumentar a acurácia de classificação entre as classes de estímulo alvo e padrão, selecionando assim as áreas corticais que melhor representam os fenômenos fisiológicos avaliados. Por fim, uma análise acerca das diferenças encontradas entre os voluntários é realizada, destacando-se assim a importância da avaliação para cada indivíduo.

II. MATERIAIS E MÉTODOS

A. Aquisição dos dados

Participaram das coletas de dados, que foram aprovadas pelo Comitê de Ética da Universidade Federal de Uberlândia por meio do número de protocolo: 17164719.4.0000.5152, cinco indivíduos saudáveis, sendo dois do sexo masculino, com idade entre 23 e 26 anos. Todos os participantes declararam não possuir histórico de perda auditiva e foram capazes de ouvir, identificar e discriminar com clareza os diferentes tons sonoros utilizados no ensaio experimental. Durante o experimento, os indivíduos foram convidados a se sentarem em uma posição confortável e ergonômica e foram instruídos a evitar qualquer movimento corporal e ocular,

mantendo-se de os olhos fechados e com total atenção à tarefa. A tarefa consistia na apresentação de tons padrões frequentes, intercalados por tons alvos não frequentes. Para realizar a tarefa, os voluntários foram solicitados a alocar recursos de atenção para o estímulo-alvo e ignorar o estímulo padrão, realizando uma contagem mental dos estímulos-alvo.

Assim, os participantes realizaram 5 tarefas auditivas de *oddball* com 5 diferentes frequências de estímulo para o estímulo alvo (100, 500, 550, 1000 e 2000 Hz), tocadas em mono na orelha direita por meio de um canal de fone de ouvido. A tarefa consistia de 50 a 55 tentativas sendo que, para cada tentativa, seis estímulos eram reproduzidos: o alvo tocado em mono e cinco pulsos de ruído branco (estímulo padrão) reproduzidos em estéreo. A duração de cada estímulo foi de 100 ms sendo a intensidade de 77 dBNSPL (nível de pressão sonora). Os intervalos entre estímulos e os intervalos entre tentativas foram randomizados entre 400 e 800 ms e 2 e 3 s, respectivamente, conforme Fig. 1.

Foi utilizada a touca MCSCAP 10-20 com anéis de fixação para o posicionamento dos eletrodos e registro dos sinais de EEG de maneira a se obter uma distribuição uniforme dos eletrodos. O sistema amplificador BE Plus LTM foi usado para condicionamento de sinal e aquisição de dados. Os dados de EEG foram coletados de 9 locais (F3, Fz, F4, C3, Cz, C4, P3, Pz e P4) de acordo com o sistema internacional de colocação de eletrodos 10-20. A taxa de amostragem foi de 1024 Hz. Os sinais foram filtrados em banda em 0,15 e 30 Hz e um filtro notch em 60 Hz foi usado

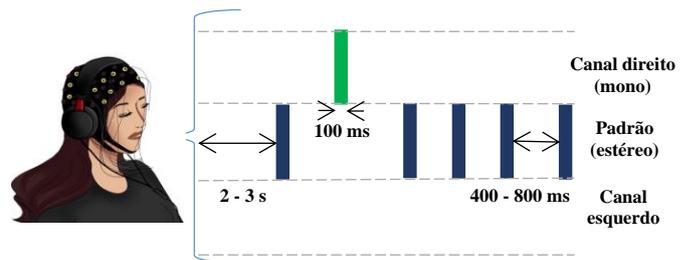


Fig. 1. Esquema de apresentação dos estímulos no paradigma *oddball* dos dois estímulos utilizados.

B. Pré-processamento dos dados

Para a remoção do artefato, os dados foram filtrados com um filtro de tendência linear e um filtro passa-banda digital de 0,75 a 18 Hz (butterworth de quarta ordem e sexta ordem, respectivamente). Um filtro stop-band de 8 a 12 Hz (butterworth de quarta ordem) foi adotado para reduzir a banda alfa. As épocas foram extraídas de todos os canais, com uma janela de tempo de 200 ms antes do início do estímulo a 800 ms após o início do estímulo. Após a segmentação, a linha de base foi corrigida subtraindo de cada época a amplitude média de -200 a 0 ms (sinal pré-estímulo). Finalmente, um limite máximo de $\pm 50 \mu\text{V}$ foi usado para validar as épocas. A amplitude e a latência do componente P300 foram medidas para cada eletrodo. Em ambas as estimativas, foram consideradas as épocas para o estímulo padrão e desviante. A amplitude do P300 foi definida como a amplitude máxima na janela de tempo entre 250 a 500 ms [16].

C. Algoritmo Genético (AG)

Os AG baseiam-se nos conceitos de população, indivíduo e adaptação. Dessa forma, a partir de uma população inicial de indivíduos, esses são avaliados para verificar sua adaptação e,

considerando as operações possíveis (cruzamento e mutação), tem-se a modificação e seleção de uma nova população [17]. Considerou-se um indivíduo composto por uma string binária de 9 elementos, na qual 1 simboliza a inclusão do eletrodo na análise e 0 sua eliminação. A função de aptidão consistiu em uma validação cruzada de 4-folds de um classificador de Máquina de Vetores de Suporte (SVM) que busca separar sinais relacionados aos estímulos alvo e padrão. Destaca-se que o mesmo conjunto de dados para treinamento e teste foi utilizado em todas as interações. Utilizou-se o elitismo dos dois melhores indivíduos ao longo da criação da nova população. Além disso, considerou-se a seleção de novos indivíduos pelo método do torneio.

Uma vez que os dados possuíam cinco épocas de estímulo padrão para uma época do estímulo alvo a cada tentativa, realizou-se a seleção aleatória de uma época do estímulo padrão para cada tentativa. Dessa forma, realizaram-se 30 execuções do algoritmo proposto, considerando a seleção aleatória das épocas de estímulo padrão. Assim, foi possível verificar um comportamento médio do sistema proposto frente as respostas de um mesmo indivíduo. Por fim, verificou-se os eletrodos que possuíram maior frequência de seleção ao longo dos testes realizados.

III. RESULTADOS E DISCUSSÕES

Visando analisar os potenciais evocados associados a cada tarefa, a Fig.2 apresenta os mapas topográficos da energia do sinal na janela de interesse (entre 250 e 350 ms) para os estímulos alvos e padrão nas diferentes frequências, considerando a média de todos os voluntários e épocas. Tais mapas foram normalizados considerando a energia máxima de todos os estímulos e canais. Nota-se a formação de dipolos mais fortes, para a maioria das frequências apresentadas, em direção ao lado contralateral no qual foi apresentado o estímulo. Além disso, no geral, energias maiores são observadas para os estímulos alvos, assim como esperado, considerando a alocação de recursos atenção e a mudança no som esperado. Existe também uma tendência mais fronto-central, com menores amplitudes nos eletrodos parietais.

Ao analisar as respostas globais, percebe-se uma clara diferença nas respostas corticais considerando as diferentes frequências dos tons alvos apresentadas. Tais diferenças tornam-se ainda mais expressivas ao avaliar as respostas corticais individuais de cada indivíduo para os estímulos apresentados. Por fim, observam-se diferenças nos potenciais evocados, destacado pela presença ou ausência de componente P300 significativo para as diferentes frequências alvo, mantendo-se todos os outros parâmetros constantes. Uma maior análise acerca das respostas corticais distintas de diferentes indivíduos para o mesmo conjunto de parâmetros de estimulação foi realizada em [18], na qual visualizou-se que os indivíduos avaliados apresentam respostas corticais diversas para os mesmos parâmetros de estimulação.

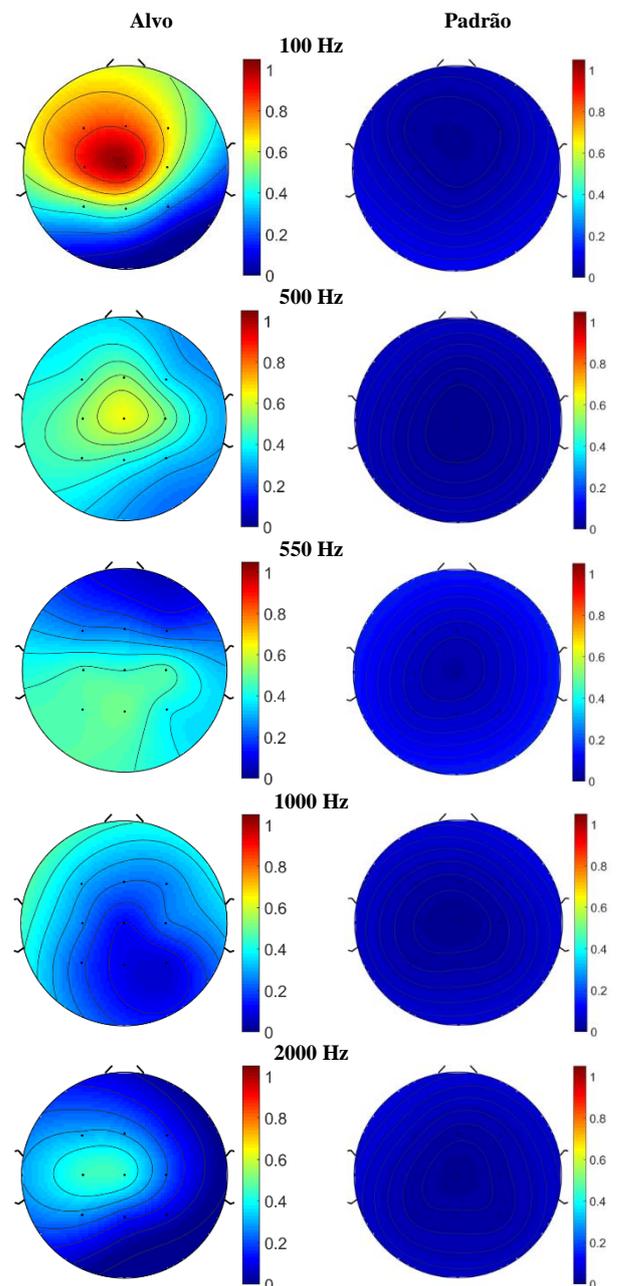


Fig. 2. Mapas topográficos da energia normalizada do sinal na janela de 250 a 350 ms para os diferentes estímulos alvos, quando apresentados no lado A (direito), considerando a média de todos os voluntários.

Assim, para a análise do desempenho do AG proposto considerou-se a variação do estímulo alvo e do número de épocas promediadas para gerar o sinal de entrada do classificador para cada voluntário. Sendo assim, observam-se na Tab 1 os resultados de média e desvio padrão da acurácia, considerando todos os eletrodos e o conjunto de eletrodos otimizados, e o número de eletrodos após a otimização, sendo o número de épocas promediadas igual a 10. É possível observar diferenças na performance dos sistemas para um mesmo indivíduo, considerando a variação das frequências do som alvo. Tais diferenças estão alinhadas com resultados anteriores que demonstram respostas corticais distintas ao variar os parâmetros de estimulação [18]–[20]. É possível observar uma redução significativa do número de eletrodos e um aumento da acurácia ao se utilizar a otimização pelo AG

proposto, existindo ainda diferenças entre as frequências e entre os voluntários.

TABELA I. MÉDIA E DESVIO PADRÃO DA ACURÁCIA E NÚMERO DE ELETRODOS PARA CADA VOLUNTÁRIO E FREQUÊNCIA, CONSIDERANDO A PROMEDIÇÃO DE 10 ÉPOCAS.

Volunt.	Frequência som alvo					
	100 Hz	500 Hz	550 Hz	1000 Hz	2000 Hz	
1	Ac. 9	91,56	78,47	90,46	85,48	98,21
	eletr.	±2,62	±5,29	±0,89	±1,33	±0,87
	Ac.	97,42	86,47	94,11	90,89	98,97
	Otim.	±1,18	±4,24	±0,66	±1,88	±0,41
	Nº eletr.	4,00	6,10	3,07	6,50	5,97
2	Ac. 9	87,01	91,39	93,73	88,72	97,24
	eletr.	±3,88	±3,16	±1,02	±3,99	±1,49
	Ac.	91,96	97,67	98,65	95,05	98,72
	Otim.	±2,32	±1,97	±0,52	±3,13	±0,74
	Nº eletr.	4,77	5,23	5,13	6,00	5,80
3	Ac. 9	90,56	85,65	93,91	95,90	92,87
	eletr.	±3,57	±4,06	±2,05	±1,89	±0,99
	Ac.	94,68	92,98	96,24	98,72	96,42
	Otim.	±2,34	±2,69	±1,12	±1,28	±0,64
	Nº eletr.	5,00	4,47	4,77	5,30	6,93
4	Ac. 9	83,63	91,63	88,85	93,75	85,73
	eletr.	±9,32	±0,55	±5,28	±0,65	±1,16
	Ac.	90,30	98,35	93,84	96,37	91,66
	Otim.	±9,87	±1,23	±3,29	±0,01	±2,48
	Nº eletr.	4,00	5,13	3,87	5,93	4,67
5	Ac. 9	91,35	94,09	84,51	92,13	87,65
	eletr.	±2,57	±3,61	±5,76	±3,01	±4,22
	Ac.	95,44	96,64	91,72	96,67	93,61
	Otim.	±2,70	±1,51	±3,74	±1,70	±2,10
	Nº eletr.	5,50	5,10	4,93	5,03	5,10

Para avaliar o impacto do número de épocas promediadas frente a geração do sinal de entrada do classificador, considerou-se a frequência de 550 Hz (uma vez que essa possui alguns dos menores números de eletrodos otimizados considerando os dados da Tab. 1) e variou-se o número de épocas para cada voluntário. Os resultados de média e desvio padrão da acurácia e número de eletrodos selecionados podem ser visualizados na Tab. 2. Observa-se assim um aumento da acurácia de classificação associado à otimização dos eletrodos de análise em todos os cenários verificados. Em especial, com somente uma época promediada (*single trial*) observa-se um aumento expressivo da acurácia de classificação, sendo essa associada a uma redução ao menos pela metade do número de eletrodos. Tal resultado pode estar associado ao fato de que as épocas de uma única tentativa são mais influenciadas pelos ruídos da atividade de *background* do EEG. Dessa maneira, os eletrodos estão mais susceptíveis a estarem contaminados com artefatos que prejudicam a visualização dos potenciais evocados como o P300. Sendo assim, a otimização dos eletrodos é capaz de selecionar somente os canais nos quais a distinção entre os potenciais associados aos estímulos alvo e padrão é mais clara e, portanto, gera uma maior acurácia. Destaca-se assim a importância da análise prévia dos eletrodos para uma seleção ótima de canais e, conseqüentemente, características que melhor descrevem a atividade neural em análise, especialmente para uma melhor performance em *single trial*.

TABELA II. MÉDIA E DESVIO PADRÃO DA ACURÁCIA E NÚMERO DE ELETRODOS PARA CADA VOLUNTÁRIO E DIFERENTES NÚMERO DE ÉPOCAS, SENDO A FREQUÊNCIA ALVO 550 HZ.

Volunt.	Número de épocas					
	1 época	3 épocas	5 épocas	7 épocas	10 épocas	
1	Ac. 9	48,67	69,75	81,34	90,22	90,46
	eletr.	±0,52	±4,03	±1,28	±5,96	±0,89
	Ac.	62,77	76,42	87,39	92,78	94,11
	Otim.	±4,24	±2,60	±1,65	±5,77	±0,66
	Nº eletr.	3,10	5,97	4,50	5,60	3,07
2	Ac. 9	47,47	72,95	75,00	78,65	93,73
	eletr.	±0,57	±1,88	±1,64	±5,85	±1,02
	Ac.	63,53	77,55	82,43	88,78	98,65
	Otim.	±3,53	±0,67	±,46	±3,86	±0,52
	Nº eletr.	2,97	5,00	6,07	5,00	5,13
3	Ac. 9	64,63	81,65	81,34	88,18	93,91
	eletr.	±3,61	±4,20	±4,35	±3,90	±2,05
	Ac.	74,10	86,25	87,68	94,09	96,24
	Otim.	±2,60	±3,65	±3,17	±2,20	±1,12
	Nº eletr.	4,60	4,50	4,33	4,50	4,77
4	Ac. 9	63,33	71,25	81,78	83,04	88,85
	eletr.	±2,40	±2,31	±1,23	±5,89	±5,28
	Ac.	68,37	75,47	85,29	83,04	93,84
	Otim.	±1,77	±1,31	±1,66	±4,05	±3,29
	Nº eletr.	3,93	3,20	4,93	5,23	3,87
5	Ac. 9	53,70	64,44	65,43	65,38	84,51
	eletr.	±6,88	±5,11	±2,48	±1,26	±5,76
	Ac.	62,00	68,73	71,70	76,71	91,72
	Otim.	±4,81	±3,47	±1,79	±0,51	±3,74
	Nº eletr.	4,53	5,10	5,27	4,93	4,93

Assim, de maneira a analisar as áreas corticais selecionadas para cada indivíduo, de acordo com a frequência de estimulação, a Fig. 3 apresenta os mapas de calor com os eletrodos selecionados ao longo das 30 execuções do AG. De forma, geral, observa-se que eletrodos distintos foram selecionados para os diferentes voluntários. Esse resultado está de acordo com a literatura, uma vez que os eletrodos selecionados podem não ser consistentes entre indivíduos [8], [10]. Apesar das divergências encontradas, nota-se uma maior prevalência de eletrodos centrais e parietais, assim como em trabalhos similares [10]. Essa prevalência está de acordo também com as regiões corticais associadas ao potencial P300 [16]. Entretanto, a utilização generalizada de somente eletrodos centro-parietais pode levar a uma redução da performance dos sistemas, uma vez que combinações e subconjuntos desses foram associadas a acurácias mais elevadas no presente trabalho. Além disso, para alguns voluntários, eletrodos na região frontal também foram selecionados pelo método de otimização, destacando mais uma vez a importância da análise prévia e individual para cada usuário de ICM. Além disso, é possível perceber uma diferença entre os eletrodos ótimos selecionados para um mesmo voluntário, considerando as diferentes frequências alvo. Tal resultado pode estar associado a respostas corticais distintas dos voluntários para os padrões de estimulação utilizados. Portanto, regiões distintas podem ser selecionadas mesmo para um mesmo indivíduo, dependendo dos parâmetros da tarefa e da atividade mental.

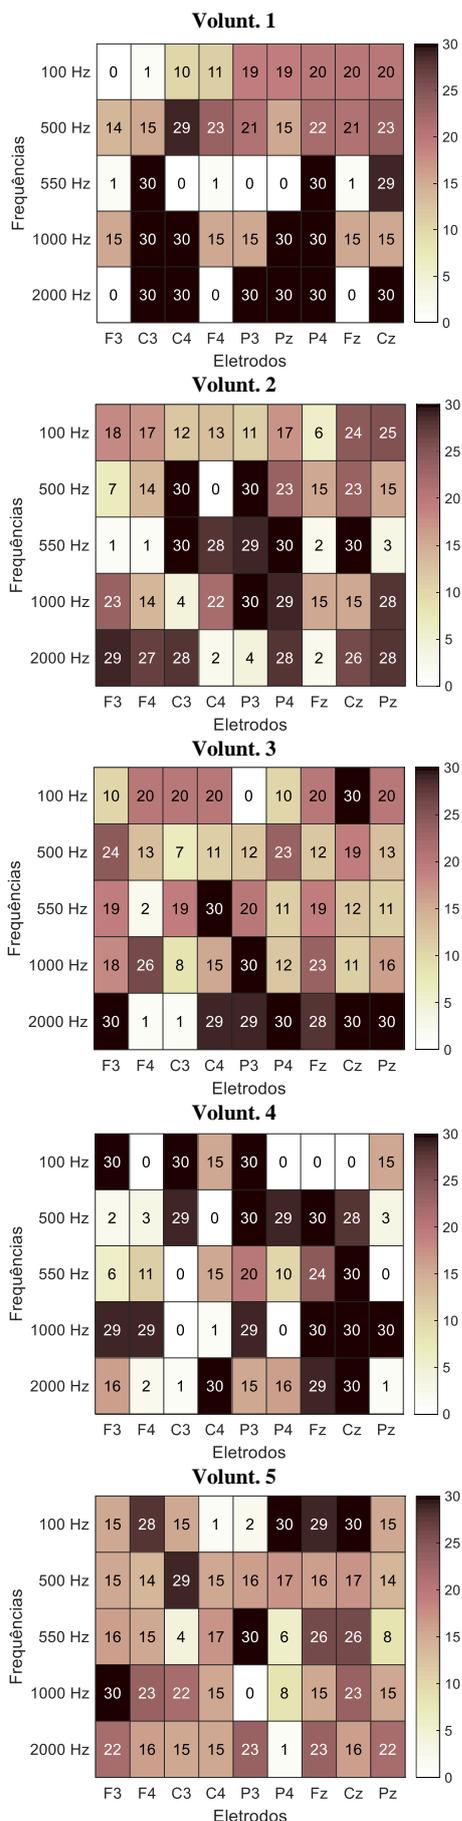


Fig. 3. Mapa de calor da seleção de eletrodos ao longo das 30 execuções do AG para cada voluntário, considerando cada frequência de estimulação.

Por fim, a Fig. 4 apresenta um gráfico de barras dos eletrodos selecionados em cada frequência, considerando a soma dos eletrodos otimizados de forma individual. De forma geral, os eletrodos com maior prevalência foram Cz, P3, P4 e Fz. Contudo, destaca-se que não é possível realizar a seleção de um mesmo conjunto de eletrodos eficaz para todos os voluntários, uma vez que não é visível uma superioridade global de nenhum canal. Tal efeito pode estar associado ao baixo número de voluntários analisados, sendo assim com um maior número de indivíduos talvez fosse possível visualizar uma maior predominância, por exemplo, do eletrodo Cz. Entretanto, argumenta-se que a melhor estratégia consiste em uma avaliação individual e anterior à utilização da ICM para cada usuário.

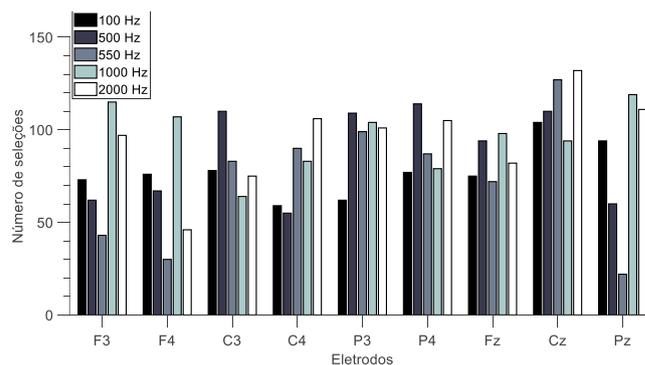


Fig. 4. Gráfico de barras da distribuição dos eletrodos selecionados pelo AG para cada frequência, considerando a soma dos eletrodos otimizados para cada indivíduo.

Métodos de otimização baseados em algoritmos evolutivos, tal como o AG proposto, possuem a vantagem de possibilitar o encontro de regiões corticais relevantes para uma determinada análise sem a necessidade de qualquer conhecimento prévio sobre o paradigma e a tarefa mental utilizada [15]. Os eletrodos ideais podem ser alcançados mais facilmente utilizando métodos de otimização, comparando com outros métodos tal como sistemas de filtragem, sendo esses eletrodos ótimos mais benéficos do que considerar canais de EEG que são conhecidos na literatura por serem responsáveis pela tarefa [13]. Além disso, os canais ótimos selecionados podem fornecer informações sobre a localização de origem dos sinais relacionados a tarefa que está sendo executada [8]. Dessa forma, o presente estudo demonstrou que, mesmo em um conjunto de eletrodos já associados a uma determinada tarefa mental (potencial P300 associado a paradigma *oddball*) é possível selecionar um subconjunto ótimo de canais que estão associados às regiões corticais de maior relevância para cada indivíduo. A otimização das áreas corticais de análise foi acompanhada de um aumento da acurácia do sistema de classificação, potencialmente devido à redução de informações redundantes ou artefatos presentes nos outros eletrodos. Uma vez que os mapas topográficos apontam para uma predominância fronto-central dos potenciais analisados, acredita-se que o aumento da acurácia pode estar associado principalmente a redução de informações redundantes.

Os trabalhos encontrados na literatura implementam algoritmos de otimização baseado em diferentes funções de aptidão, sendo essas associadas ao erro [9] ou acurácia [12] de um classificador e número de eletrodos, dados estatísticos

[10], dentre outros. A utilização de uma função de aptidão baseada na acurácia de um classificador permite assim a identificação de canais de EEG que possibilitam uma maior performance de uma ICM, associando o processo de otimização ao processo de separação de respostas corticais. Tal redução visa tornar os sistemas mais compactos, rápidos e confortáveis para o usuário final. Sabe-se que os projetos de ICMs geralmente não integram explicitamente as preferências e experiências do usuário na elaboração do sistema, sendo esse um dos prováveis motivos para desistência de utilização dos mesmos [4]. Sendo assim, a seleção ótima de eletrodos possibilita não somente uma maior usabilidade e eficácia da ICM, como também um maior conforto e satisfação do usuário. Portanto, essa análise prévia acerca do posicionamento dos eletrodos, preferencialmente por sistemas automatizados, deve estar presente no processo de elaboração de ICM mais adaptáveis a cada usuário final.

IV. CONCLUSÕES

O algoritmo de otimização proposto combina um algoritmo genético e uma SVM para avaliar um conjunto de eletrodos associados a tarefas de paradigma *oddball* auditivo. Esse permitiu a identificação de áreas corticais ótimas para análise e performance de um sistema de classificação das respostas neurais. Os resultados apontam para a dependência da seleção de acordo com o indivíduo e, portanto, métodos automatizados são importantes ferramentas para uma análise prévia do melhor subconjunto de eletrodos para cada usuário. Tal ferramenta pode assim aumentar a usabilidade de ICM, garantindo ainda maior conforto e satisfação para o usuário.

AGRADECIMENTOS

Agradecimentos à CNPQ, CAPES e FAPEMIG, pelo apoio financeiro e à Universidade Federal de Uberlândia (UFU) e ao BIOLAB-FEELT-UFU pela disponibilização de estrutura física.

REFERÊNCIAS

[1] M. Marchetti and K. Priftis, "Brain-computer interfaces in amyotrophic lateral sclerosis: A metaanalysis," *Clin. Neurophysiol.*, vol. 126, no. 6, pp. 1255–1263, 2015, doi: 10.1016/j.clinph.2014.09.017.

[2] F. Lotte *et al.*, "A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update," *J. Neural Eng.*, vol. 15, no. 3, p. aab2f2, 2018, doi: 10.1088/1741-2552/aab2f2.

[3] E. V. Hobson and C. J. McDermott, "Supportive and symptomatic management of amyotrophic lateral sclerosis," *Nat. Rev. Neurol.*, vol. 12, no. 9, pp. 526–538, 2016, doi: 10.1038/nrneuro.2016.111.

[4] V. Johansson, S. R. Soekadar, and J. Clausen, "Locked Out," *Cambridge Q. Healthc. Ethics*, vol. 26, no. 4, pp. 555–576, 2017, doi: 10.1017/S0963180117000081.

[5] R. N. Bertazzi, F. R. Martins, S. Z. Z. Saade, and V. R. Guedes, "Esclerose lateral amiotrófica," *Rev. Patol. do Tocantins*, vol. 4, no. 3, p. 54, Sep. 2017, doi: 10.20873/uft.2446-6492.2017v4n3p54.

[6] A. Spirandeli, "Detecção e classificação de potenciais evocados auditivos baseadas em filtros casados," Universidade Federal de Uberlândia, 2020.

[7] R. Abiri, S. Borhani, E. W. Sellers, Y. Jiang, and X. Zhao, "A comprehensive review of EEG-based brain-computer interface paradigms," *J. Neural Eng.*, vol. 16, no. 1, 2019, doi: 10.1088/1741-2552/aaf12e.

[8] S. Fathima and S. K. Kore, "Formulation of the Challenges in Brain-Computer Interfaces as Optimization Problems—A Review," *Front. Neurosci.*, vol. 14, no. January, pp. 1–13, 2021, doi: 10.3389/fnins.2020.546656.

[9] O. P. Idowu *et al.*, "Neuro-evolutionary approach for optimal selection of EEG channels in motor imagery based BCI application," *Biomed. Signal Process. Control*, vol. 68, no. March, 2021, doi: 10.1016/j.bspc.2021.102621.

[10] I. H. Hasan, A. R. Ramli, and S. A. Ahmad, "Utilization of Genetic Algorithm for Optimal EEG Channel Selection in Brain-Computer Interface Application," *Proc. - 2014 4th Int. Conf. Artif. Intell. with Appl. Eng. Technol. ICAIET 2014*, pp. 97–102, 2014, doi: 10.1109/ICAET.2014.25.

[11] C. Y. Kee, S. G. Ponnambalam, and C. K. Loo, "Multi-objective genetic algorithm as channel selection method for P300 and motor imagery data set," *Neurocomputing*, vol. 161, pp. 120–131, 2015, doi: 10.1016/j.neucom.2015.02.057.

[12] A. Albasri, F. Abdali-Mohammadi, and A. Fathi, "EEG electrode selection for person identification thru a genetic-algorithm method," *J. Med. Syst.*, vol. 43, no. 9, 2019, doi: 10.1007/s10916-019-1364-8.

[13] T. Alotaiby, F. E. A. El-Samie, S. A. Alshebeili, and I. Ahmad, "A review of channel selection algorithms for EEG signal processing," *EURASIP J. Adv. Signal Process.*, vol. 2015, no. 1, 2015, doi: 10.1186/s13634-015-0251-9.

[14] L. A. Moctezuma and M. Molinas, "Towards a minimal EEG channel array for a biometric system using resting-state and a genetic algorithm for channel selection," *Sci. Rep.*, vol. 10, no. 1, pp. 1–14, 2020, doi: 10.1038/s41598-020-72051-1.

[15] C. Y. Kee, R. M. Kuppan Chetty, B. H. Khoo, and S. G. Ponnambalam, "Genetic algorithm and Bayesian linear discriminant analysis based channel selection method for P300 BCI," *Commun. Comput. Inf. Sci.*, vol. 330 CCIS, pp. 226–235, 2012, doi: 10.1007/978-3-642-35197-6_25.

[16] J. Polich, "Clinical application of the P300 event-related brain potential," *Phys. Med. Rehabil. Clin. N. Am.*, vol. 15, no. 1, pp. 133–161, 2004, doi: 10.1016/S1047-9651(03)00109-8.

[17] M. TOMASSINI, "A survey of genetic algorithms," *Annu. Rev. Comput. Phys. III*, pp. 87–118, 1995, doi: 10.1142/9789812830647_0003.

[18] J. N. Mello, A. F. Spirandeli, H. de C. Neto, C. B. Amorim, and A. B. Soares, "Identical Auditory Stimuli Render Distinct Cortical Responses Across Subjects – an Issue for Auditory Oddball-Based BMIs," 2020.

[19] N. Novitski, M. Tervaniemi, M. Huotilainen, and R. Näätänen, "Frequency discrimination at different frequency levels as indexed by electrophysiological and behavioral measures," *Cogn. Brain Res.*, vol. 20, no. 1, pp. 26–36, 2004, doi: 10.1016/j.cogbrainres.2003.12.011.

[20] M. J. Sugg and J. Polich, "P300 from auditory stimuli: intensity and frequency effects," *Biol. Psychol.*, vol. 41, no. 3, pp. 255–269, 1995, doi: 10.1016/0301-0511(95)05136-8.